

DOI:10.13296/j.1001-1609.hva.2021.04.005

基于深层卷积神经网络的电工钢片矢量磁特性模拟

董纪兴, 张殿海, 任自艳, 张艳丽

(沈阳工业大学辽宁省现代电工装备理论与共性技术重点实验室, 沈阳 110870)

摘要: 针对传统基于BP神经网络磁滞模型收敛速度慢、建模过程需要对磁特性的表征参数进行复杂的人工提取等问题,提出了一种基于深层卷积神经网络的电工钢片矢量磁滞特性模拟的方法,该模型将磁通密度的时间序列数据和磁场强度的幅值和相位作为卷积神经网络的训练数据,利用残差模块提高卷积神经网络的收敛速度。改进模型既可以避免传统磁滞模型中繁杂的人工特征提取的过程,也可拓展应用于特征参数不易提取的非正弦激励下磁滞模型的建立。通过对比不同网络结构的磁滞模型,改进的深层卷积网络磁滞模型既能减少迭代次数,又能保证磁滞特性模拟的精细性。

关键词: 矢量磁滞模型; 电工钢片; 卷积神经网络; 残差模块

Vector Magnetic Characteristics Simulation of Electrical Steel Sheet Based on Deep Convolutional Neural Network

DONG Jixing, ZHANG Dianhai, REN Ziyang, ZHANG Yanli

(Liaoning Key Laboratory of Modern Electrical Equipments Theory and Common Technologies, Shenyang University of Technology, Shenyang 110870, China)

Abstract: In view of such problems of traditionally BP neural network-based magnetic hysteresis model as slow convergence speed and complicated artificial extraction of characterization parameters of magnetic characteristic in the modeling process, a kind of method to simulate the vector hysteresis characteristic on the basis of deep convolutional neural networks (DCNN) is proposed. The model takes the time series data of magnetic flux density and amplitude and phase of the magnetic field strength as the training data of the convolutional neural networks (CNN). The residual error module is used to improve the convergence speed of convolution neural network. The improvement of the model can not only avoid the complicated artificial feature extraction process in the traditional magnetic hysteresis model, but also extend and apply for the setup of hysteresis models under non-sinusoidal excitation whose characteristic parameters are not easy to extract. It is founded through the comparison of magnetic hysteresis model of different network structures that the improved DCNN magnetic hysteresis model can not only reduce the number of iterations, but also assure refinement of the magnetic hysteresis behavior simulation.

Key words: vector magnetic hysteresis model; electrical steel sheet; convolutional neural networks; residual module

0 引言

以电工钢片为代表的电工磁性材料广泛应用于电机、变压器等电工装备的铁心部件中,这类磁性材料的应用和结构设计直接影响电工装备的电

气性能和可靠性。而解决这些问题的关键是要建立精细的材料特性数学模型。

目前国内的电工钢片生产企业都是以国家标准提供产品的测量数据,这些数据都是在交变磁化下获得的,即假设磁通密度 B 和磁场强度 H 的方向

收稿日期:2020-11-04; 修回日期:2020-12-27

基金项目:国家自然科学基金(51707125);辽宁省高等学校创新人才支持计划(LR2017060).

Project Supported by the National Natural Science Foundation of China Under Grants(51707125), Program funded by Ministry of Education in Liaoning Province Under Grant(LR2017060).

一致。实际上,在电机、变压器的实际运行过程中还存在着大量旋转磁场,即磁场强度 H 和磁通密度 B 之间存在夹角^[1]。在模拟电工钢片复杂磁特性仅采用标准的测量数据会产生一定的误差,因此实现电工钢片矢量磁特性的测量是精确模拟电工钢片复杂磁特性的前提。

由于电工钢片在制备和加工的过程中,会造成材料内部存在杂质和缺陷,导致磁化过程中发生磁畴的不可逆转动和畴壁的不可逆位移,引起磁通密度变化滞后于磁场强度变化的磁滞现象^[2]。为了能够精确地模拟磁性材料的磁滞现象,国内外学者提出了许多描绘磁滞特性的数学模型,最常用的磁滞模型主要有3类,包括:Preisach 磁滞模型、Jiles-Atherton 磁滞模型和 E&S 磁滞模型。经典的 Preisach 磁滞模型和 J-A 磁滞模型是标量模型,即不能表征磁性材料的各向异性也无法描述外磁场方向上的变化。E&S 磁滞模型是近些年由日本学者 Enokizono M 提出的,虽然它是矢量磁滞模型,但过于依赖实验数据,难以被拓展应用。国内外学者围绕这三大类磁滞模型也不断提出一系列修正模型^[3-6]和考虑应力、温度等外界因素模型^[7-8]。

神经网络磁滞模型是近几年提出的一种模拟电工钢片复杂磁特性的新方法。因为神经网络技术可以实现对复杂非线性函数的高度拟合,而磁性材料的磁滞现象本身就是一个复杂的非线性问题,即在给定的磁通密度 B 的情况下,通过神经网络预测相对应的磁场强度 H 的轨迹。文[9]通过预先建立一个不考虑任何磁滞现象的 B_x-B_y 到 $\hat{H}_x-\hat{H}_y$ 的神经网络模型,然后再建立一个单独用来体现磁滞现象的神经网络模型来预测 $\hat{H}$ 的两个分量,通过两种不同的神经网络的组合模型来实现电工钢片复杂磁特性的模拟。文[10]针对传统神经网络收敛速度慢和模型容易陷入局部最优的缺点,提出了神经网络与粒子群算法相结合的协同 BP 神经网络磁滞模型;文[11]利用 BP 神经网络技术和遗传算法相结合改进 Jiles-Atherton 磁滞模型的相关参数。

虽然 BP 神经网络可以在处理一些复杂的问题上具有强大的学习能力,但自身也存在着一些缺陷。当输入数据量过大,权值过多,会出现收敛缓慢或无法计算的问题,就需要人工对数据进行预处理。但在人工预处理的阶段就可能丢失深层次的特征信息,导致出现过拟合的问题,即过度训练,处理训练过的数据表现良好,但处理未被训练的数据会产生较大误差。

文中提出一种基于深层卷积神经网络的磁滞模型,利用卷积神经网络强大的自主提取特征的优点,实现对电工钢片复杂磁特性的精确模拟。该模型具有训练时间短、学习泛化能力强、鲁棒性强、以及更加适用于工程实际等优点。

1 电工钢片矢量磁特性测量

测量装置和椭圆磁场见图1。图1给出了一种两个方向共同励磁的二维矢量磁特性测量装置,装置采用4个可伸缩的金属探针,分别探测沿电工钢片的轧制方向(rolling direction, RD)和垂直于轧制方向(transverse direction, TD)的信号。测量时分别给 RD 方向和 TD 方向的磁化绕组施加激励电流,通过 RD 方向和 TD 方向的 B 线圈和 H 线圈的感应电势分别得到 B 和 H 的波形,再经过矢量合成得到矢量 B 和矢量 H 。

大量的文献表明,在电机和变压器的运行过程中交变磁场和旋转磁场是同时存在的,这两种磁场的叠加共同组成了椭圆磁场^[12],即一个磁化周期内,磁通密度 B 的轨迹为椭圆。




图1 测量装置和椭圆磁场

Fig. 1 Measurement apparatus and ellipse magnetic field

其中 $B_{\max}$ 为磁通密度椭圆轨迹的长轴, θ_B 为椭圆长轴与电工钢片轧制方向的夹角, α 为短轴与长轴之比,通常称作轴比。改变 $B_{\max}$, α 和 θ_B 的值就可以得到不同形状的椭圆轨迹,磁通密度 B 的轨迹可由 $B_{\max}$ 、 α 、 θ_B 这3个特征参数直接进行描述。

为了在测量过程中产生椭圆磁场,沿着轧制方向和垂直于轧制方向的磁通密度 $B_x(t)$ 和 $B_y(t)$ 的波形分别控制为

$$\begin{cases} B_x(t) = B_{\max} \cos \theta_B \cos \tau - \alpha B_{\max} \sin \theta_B \sin \tau \\ B_y(t) = B_{\max} \sin \theta_B \cos \tau + \alpha B_{\max} \cos \theta_B \sin \tau \end{cases} \quad (1)$$

式(1)中, $\tau = \omega t$, ω 为激励电源的频率, t 为时间。

这种电工钢片二维矢量磁特性的测量装置相较于传统的单方向测量装置,如爱泼斯坦方圈,更贴近电工设备实际运行过程中磁通密度 B 和磁场强

度 H 的波形。

2 基于卷积神经网络的磁滞模型

2.1 卷积神经网络

卷积神经网络是一种对网格形式数据实现卷积操作的深度学习网络框架。其优点在于可以直接将二维像素网络的图像作为网络的输入,避免了传统识别算法中需要对图像进行复杂的人工特征提取和数据重构的过程,使得在二维图像的处理中具有极大的优势。经典卷积神经网络的隐藏层中主要包括卷积层、池化层和全连接层,卷积神经网络的结构见图2。




图2 卷积神经网络基本流程

Fig. 2 Basic process of convolutional neural network

卷积层是卷积神经网络中核心模块之一,它由多个卷积核组成。卷积核实质上是一个数值矩阵,矩阵中的每一值都是对输入到卷积层中的二维矩阵中通过卷积操作学习到的权值,每一个卷积核都有着不同的权值,而且每个卷积核都可以生成相应的二维特征矩阵,对应的数学描述见式(2)

$$x^l = \sum_{i \in M} w^l * z^{l-1} + b^l \quad (2)$$

式(2)中: $*$ 表示卷积算子; x^l 表示卷积操作后输出矩阵; M 代表局部感受野; w 表示卷积核; b 表示偏置系数; z^{l-1} 表示二维输入矩阵或上一层的特征矩阵。

为了能够提取最具有代表性的特征,一般都会在卷积层之后添加池化层。因为经由卷积层输出的特征矩阵包含了周边区域信息,而池化层可以有效地去除这些冗余信息,提升了整体网络的鲁棒性和泛化能力。通常卷积神经网络中的池化层都采用最大池化,其数学描述见式(3)

$$z^l = \max_{0 \leq n \leq \frac{L}{S}} \{z^{l-1}[nW, (n+1)W]\} \quad (3)$$

式(3)中: z^l 为最大池化后的特征矩阵; z^{l-1} 为卷积层输出的特征矩阵; W 代表池化操作的窗口大小; S 代表池化操作的步幅。

全连接层一般作为卷积神经网络隐藏层中的最后几层,经由卷积和池化后的二维特征矩阵平铺成一维特征向量作为全连接层的输入,层中的神经元与前一层的所有神经元进行全连接,其数学描述

见式(4)

$$x_j^l = \sum_{i=1}^n w_{ij}^l z_i^{l-1} + b_j^l \quad (4)$$

式(4)中: x_j^l 为这一层第 j 个神经元的线性输出; z_i^{l-1} 为上一层第 i 个神经元的输出; w_{ij}^l 为第 j 个神经元与第 i 个神经元之间的权重; b_j^l 为上一层所有神经元对这一层第 j 个神经元的偏置。

激活函数是神经网络中引入非线性转换的关键,它可以增强模型的拟合能力,提升整体网络的表达能力,通常出现在卷积层和全连接层中。

$$z^l = f(x^l) \quad (5)$$

式(5)中: $f(\cdot)$ 表示激活函数; z^l 表示在非线性变换后的特征矩阵或特征向量。

常用的激活函数主要有:sigmoid、tanh、ReLU,其数学表达式为:

$$\text{sigmoid} = \frac{1}{1 + e^x} \quad (6)$$

$$\text{tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7)$$

$$\text{ReLU} = \max(0, x) \quad (8)$$

sigmoid激活函数和tanh激活函数都是将特征信息压缩到某一特定的区间来实现非线性的转化,但在特定区间的两端会出现饱和区域,可能会导致梯度消失的问题,而ReLU激活函数的出现可以更好地避免这一问题。卷积神经网络中不同的层可以根据情况选择不同的激活函数。

卷积神经网络作为具有一种深层结构的神经网络模型,卷积层和池化层组成的特征提取器具有稀疏连接和权值同享的优点,这些层的参数之间是非全连接的,这样可以大幅度减少模型中需要训练的参数,降低了网络复杂度,从而地降低计算复杂度,进而提高了模型的学习速率,因此能够实现对高维数据的深层次特征提取,同网络拥有很强的并行处理能力。正因为这些优越的性能使得卷积神经网络在图像识别和分类、模式识别、故障诊断等相关研究领域中的表现超越了机器学习的其他方法^[13-16]。在2020年人类与新型冠状病毒疫情的对抗中,基于卷积神经网络的CT影像病灶检测模型凭借其完成病例自动检测的快速性,得到初步筛查结果的准确性,在缓解医疗资源紧张,控制疫情的蔓延具有重大意义^[17]。

2.2 深层卷积神经网络

从理论上讲,随着网络宽度和深度的增加,模型的性能应该会表现得越来越好。但通过大量的实验验证,如果只是简单地增加网络的深度,神经网络的性能反而会出现下降的现象。主要是因

为过深的网络结构势必会存在一些冗余层,这些冗余层一旦没有成功学习特征信息,就会造成到整体性能的断崖式下降,甚至可能会出现学习效果比浅层网络还要差的现象。

为了解决这一问题,文[18]提出了一种残差卷积神经网络,核心思想是在卷积神经网络中添加可以实现跨层连接的残差模块,使得卷积神经网络中的特征信息可以在各个层之间无障碍地跨越,这种连接方式也可以让梯度在网络中得到更好地传播。残差模块的具体构造见图3。




图3 残差模块

Fig. 3 Residual module

设 $H(x)$ 表示目标拟合函数, $F(x)$ 表示残差项, $H(x)$ 与 $F(x)$ 之间的关系为

$$H(x) = F(x) + x \quad (9)$$

这样就将拟合 $H(x)$ 的问题转变为不断逼近 $H(x)-x$ 的问题,使得浅层网络的特征在深层网络得到重用。在 $F(x) \rightarrow 0$ 时,也仅会退化为 $H(x)=x$,确保深层网络的学习效果至少不会比浅层网络差。

2.3 基于深层卷积神经网络的磁滞模型

文中基于深层残差卷积神经网络提出模拟电工钢片复杂磁特性的建模方法,训练过程可以大致分为3步:①将实验装置测得的磁通密度和磁场强度的幅值和相位直接输入到卷积神经网络的模型中;②通过反向传播算法实现模型的训练,自主提取和学习磁通密度 B 和磁场强度 H 之间的磁特性关系;③保存训练完成的磁滞模型,用于实现电工钢片复杂磁特性的模拟。

实验装置测量得到的磁通密度 B 作为卷积神经网络磁滞模型的输入,但由于 $B_x(t)$ 和 $B_y(t)$ 是两列含有2 048个点的时间序列数据,因此需要将 $B_x(t)$ 和 $B_y(t)$ 转化为符合卷积神经网络的网格数据输入形式,因此将每组样本中的4 096个数据点转化为 64×64 的二维矩阵。另一方面,为了能够减少网络中的参数,缩短计算时间,选择将傅里叶变换后磁场强度 H 的幅值和相位作为卷积神经网络训练过程中的标签,网络输出的结果最终需要通过逆傅里叶变换后

得到相应的 $H_x(t)$ 和 $H_y(t)$ 。卷积神经网络磁滞模型的预测流程见图4。




图4 预测流程

Fig. 4 The prediction process

为了精确地描绘磁场强度 H 的轨迹,训练数据中的磁场强度 H 考虑到15次谐波。而且磁场强度 H 的波形中只含有奇次谐波,所以深层卷积神经网络磁滞模型的输出为32个节点,隐藏层中卷积层、和全连接层的激活函数都选取的是ReLU,在输出层采用的是线性激活函数Linear,在输出层用于数据拟合中常用的一种函数。

该模型不仅仅局限于舍弃传统磁滞模型中繁杂的人工提取特征参数的过程。之前所提到交变磁场和椭圆磁场在沿着轧制方向和垂直于轧制方向上均是以正弦磁场作为测量标准,是属于正弦磁场激励的二维磁特性测量法,然而在电工设备实际的运行过程中,电源在设备中的分布情况和电源的波形,以及铁磁构件的复杂磁特性,都会导致铁心部件的磁场产生谐波,使得磁通密度的时间曲线呈现非正弦。这种复杂情况的存在极大限制了传统磁滞模型在实际工程中的应用。而文中提出的可直接将磁通密度的测量数据作为输入的深层卷积神经网络磁滞模型在模拟非正弦磁场下电工钢片的复杂磁特性具有巨大潜力。

3 实验验证

3.1 结果比较

参与深层卷积神经网络磁滞模型训练的磁通密度 B 轨迹各参数的变化情况为见表1。如表1所示, θ_b 以 15° 为间隔,测量范围为 $0 \sim 90^\circ$; α 的取值为 $0 \sim 1$,间隔为 0.2 ; $B_{\max}$ 的取值为 $0.5 \sim 1.4$ T。磁通密度 B 轨迹见表1。任意4种未参与模型训练的测量数据,这4种轨迹下,深层卷积神经网络磁滞模型预测的 H 波形和测量数据的比较见图5。图5结果显示,模型计算的结果可以很好地与测量结果相吻合。

表1 任意选取的4种 B 的轨迹Table 1 Four different B locus

B 轨迹	$B_{\max}/T$	α	$\theta_b/(^\circ)$
a	0.9	0.2	15
b	1.3	0.0	30
c	0.5	0.6	45
d	0.9	0.6	75




图5 模拟与测量结果的比较

Fig. 5 Comparison of simulation and measurement results

3.2 性能分析

不同网络结构神经网络的损失对比见表2。为了分析不同的网络结构对于神经网络磁滞模型性能的影响,表2给出了参数选定比较合适的不同网络结构的神经网络的迭代次数和训练时间,虽然深层卷积神经网络减少了迭代次数,但也因为层数的增加,每次迭代的计算量增大,导致所需的训练时间相较于浅层神经网络更长。

表2 不同网络结构神经网络的性能对比

Table 2 Performance comparison of neural networks with different network structures

神经网络类型	迭代次数	训练时间/s
CNN	150	64
DCNN	80	102

不同神经网络结构下神经网络磁滞模型在前500步的均方误差见图6。可以看到,引入残差模块后的深层神经网络磁滞模型的误差下降速度明显加快,且迭代结束后的误差小于浅层神经网络。尽管训练时间有所增加,但深层卷积神经网络相较于浅层卷积神经网络在电工钢片复杂磁特性的模拟中能够达到更高的精度。

4 结语

文中提出一种基于深层卷积神经网络模拟电




图6 不同网络结构神经网络的损失对比

Fig. 6 Loss comparison of neural networks with different network structures

工钢片复杂磁特性的建模方法。该模型可以直接输入磁通密度时间序列数据从而获得相应磁场强度。相较于以往的神经网络磁滞模型,省去了人工提取磁通密度特征参数的过程,实现对电工钢片磁滞特性特征的自主提取和学习,而且该模型也可适用于磁通密度包含谐波的复杂情况。文中分析了不同网络结构下神经网络磁滞模型的性能,结果表明:加入残差模块的深层卷积神经网络磁滞模型既可以加快收敛速度、减少迭代次数,又能够保证模拟的精细性,是一种更加适用于工程应用的磁滞模型。

参考文献:

- [1] 乔振阳, 李丹丹, 杨娜, 等. 电工磁材料磁滞数学模型的研究综述[J]. 电工材料, 2020(1): 8-12.
QIAO Zhenyang, LI Dandan, YANG Na, et al. A review of research on magnetic hysteresis mathematical model of magnetic materials in electrical engineering[J]. Electrical Engineering Materials, 2020(1): 8-12.
- [2] 段建东, 雷阳, 李浩, 等. 铁磁元件J-A模型的研究发展与趋势[J]. 高压电器, 2020, 56(12): 16-23.
DUAN Jiandong, LEI Yang, LI Hao, et al. Review of ferromagnetic components J - A model[J]. High Voltage Apparatus, 2020, 56(12): 16-23.
- [3] 段娜娜, 徐伟杰, 李永建, 等. 基于极限磁滞回线法的软磁复合材料磁特性模拟[J]. 电工技术学报, 2018, 33(20): 4739-4745.
DUAN Nana, XU Weijie, LI Yongjian, et al. Electromagnetic property modeling of the soft magnetic composite material based on the limiting loop method[J]. Transactions of China Electrotechnical Society, 2018, 33(20): 4739-4745.
- [4] 王旭, 张艳丽, 唐伟, 等. 旋转磁化下逆矢量Jiles-Atherton磁滞模型改进[J]. 电工技术学报, 2018, 33(s2): 257-262.
WANG Xu, ZHANG Yanli, TANG Wei, et al. Improvement of inverse vector Jiles-Atherton hysteresis model under rotating magnetization[J]. Transactions of China Electrotechnical Society, 2018, 33(s2): 257-262.
- [5] KAI Y, ENOKIZONO M. Effect of arbitrary shear stress on vector magnetic properties of a non-oriented electrical steel sheet[J]. IEEE Transactions on Magnetics, 2017, 53(11): 2002304.
- [6] 刘力卿, 何思名, 冯军基, 等. 一种快速高鲁棒性变压器铁心Jiles-Atherton磁滞模型参数辨识方法[J]. 高压电器, 2020, 56(1): 5-60.
LIU LiQing, HE Siming, FENG Junji, et al. Fast and robust parameter identification method for Jiles-Atherton hysteresis model of transformer core[J]. High Voltage Apparatus, 2020, 56(1): 5-60.
- [7] ZHANG Dianhai, JIA Mengfan, LIU Yang, et al. Comprehensive improvement temperature-dependent Jiles-Atherton model utilizing variable model Parameters[J]. IEEE Transactions on Magnetics, 2018, 54(3): 7300504.
- [8] ENOKIZONO M. Vector magnetic characteristic analysis by using complex E&S model taking account of stress effect[J]. Journal of the Japan Society of Applied Electromagnetics and Mechanics, 2015, 23(3): 436-441.
- [9] CARDELLIA E, FABA A, LAUDANI A, et al. Two-dimensional magnetic modeling of ferromagnetic materials by using a neural network based hybrid approach[J]. Physica B Condensed Matter, 2016(486): 106-110.
- [10] CHI Lianqiang, ZHANG Dianhai, JIA Mengfan, et al. Implementation of vector hysteresis model utilizing enhanced neural network based on collaborative algorithm[J]. IEEE Access, 2020, 8(1): 34162-34169.
- [11] 杨延菊. 基于神经网络的Jiles-Atherthon磁滞模型的实现[D]. 北京: 华北电力大学, 2012.
YANG Yanju. Implement of Jiles - Atherthon hysteresis model based on neural network[D]. Beijing: North China Electric Power University, 2012.
- [12] 张殿海, 贾梦凡, 任自艳, 等. 无取向电工钢应力依赖矢量磁特性测量研究[J]. 电工技术学报, 2019, 34(s2): 449-456.
ZHANG Dianhai, JIA Mengfan, REN Ziyang, et al. Investigation on measurement of stress dependent vector magnetic properties of non-oriented electrical steel sheet[J]. Transactions of China Electrotechnical Society, 2019, 34(s2): 449-456.
- [13] KUKHARENKO A I, KONUSHIN A. Simultaneous classification of several features of a person's appearance using a deep convolutional neural network[J]. Pattern Recognition and Image Analysis, 2015, 25(3): 461-465.
- [14] 杨柏, 关焕新, 王森, 等. 基于深层卷积神经网络电动飞机主驱动电机故障诊断方法[J]. 微电机, 2020, 53(3): 49-54.
YANG Bo, GUAN Huanxin, WANG Sen, et al. Fault diagnosis method for main drive motor of electric aircraft based on deep convolutional neural network[J]. Micromotors, 2020, 53(3): 49-54.
- [15] 杨为, 朱太云, 张国宝, 等. 电力物联网下基于卷积神经网络和迁移学习的GIS局部放电模式识别分类方法研究[J]. 高压电器, 2020, 56(9): 20-25.
YANG Wei, ZHU Taiyun, ZHANG Guobao, et al. Research on partial discharge pattern recognition and classification in GIS based on convolutional neural network and transfer learning in power internet of things[J]. High Voltage Apparatus, 2020, 56(9): 20-25.
- [16] 丁石川, 厉雪衣, 杭俊, 等. 深度学习理论及其在电机故障诊断中的研究现状与展望[J]. 电力系统保护与控制, 2020, 48(8): 172-187.
DING Shichuan, LI Xueyi, HANG Jun, et al. Deep learning theory and its application to fault diagnosis of an electric machine[J]. Power system Protection and Control, 2020, 48(8): 172-187.
- [17] 祖莅惠, 胡博奇, 王平, 等. 基于深度学习的新型冠状病毒肺炎CT征象检测研究[J]. 中国医疗设备, 2020, 35(6): 89-92.
ZU Lihui, HU Boqi, WANG Ping, et al. Study of covid-19 CT imaging detection based on deep learning[J]. China Medical Devices, 2020, 35(6): 89-92.
- [18] CHEOLSUM K, DONGJU P, HEUNG - NOL. Compressive sensing spectroscopy using a residual convolutional neural network[J]. Sensors, 2020, 20(3): 594.

董纪兴(1994—),男,硕士,研究方向为电工钢片复杂磁特性测量和模拟(E-mail:1536284718@qq.com)。

张殿海(1984—),男,副教授,博士生导师,主要研究方向为电工磁性材料电磁特性测量与模拟、电工装备电磁场数值分析与计算(通信作者)(E-mail:zdh700@126.com)。